




Euroopan unioni
Euroopan aluekehitysrahasto



ETELÄ-POHJANMAAN LIITTO
Regional Council of South Ostrobothnia

Vipuvoimaa
EU:lta
2014–2020



Alumiiniprofiilien laadunvalvonta Deep Learning -menetelmällä

Laadusta kilpailukykyä konenäöllä (LAAKI) -hanke

SeAMK

SEINÄJOEN AMMATTIKORKEAKOULU
SEINÄJOKI UNIVERSITY OF APPLIED SCIENCES

Lähtökohdat

- Alumiiniprofiilien valmistuksessa saattaa esiintyä laatupoikkeamia
- PoCin tavoitteena oli tutkia erilaisten virheiden tunnistettavuutta Deep Learning -menetelmällä
- Ympäristö rakennettiin kiinteäksi, jolloin erilaisia profiileita ja niiden virheiden tunnistettavuutta voitiin arvioida yhdellä valaisin- ja laiteasettelulla.




Lähtökohdat

- Testaus tehtiin muutamalla eri muotoisella profiililla ja eri tyyppisellä laatuvirheellä
- Testikappaleiden pinta ei vastaa profiilipursottimelta tulevan materiaalin pintaa, koska testikappaleiden käsittely ja kuljetus muokkaa pintaa siten, että siinä on visuaalisia poikkeamia, jotka eivät ole laatuvirheitä, mutta näkyvät kuvassa.



Testausympäristö

- Testausympäristössä koostui seuraavista komponenteista:
 - Basler acA1600-60gc -kamera (resoluutio 1600x1200)
 - Kaksi paneelivalaisinta
 - Ohjelmisto MVTech Merlic + Deep Learning -lisäosa
 - PoE-injektori



Kameran kytkentä

- Kamera saa virransyötön PoE-injektorilla verkkokaapelinkautta. Sama kaapeli toteuttaa myös dataliikenteen kameran ja tietokoneen välillä
- Kamerarajapinta on GigE

Tietokoneelle

Kameralle



Kuvalähteen määrittely ohjelmistossa

- Kuvalähde määritellään Merlicissä Image Source -toiminnolla
- Recipes-toiminolla voidaan määritellä eri ohjelmia esimerkiksi eri tuotteille ja kutsua niitä rajapinnan kautta
- Kuvalähteitä voidaan määritellä useampia eri kameroille tai eri asetuksilla
- Työkalulla voidaan säätää pääsääntöisesti kuvanottoon liittyviä kameraparametreja.
 - Yleisin parametri on valotusaika, joka tässäkin säädettiin analyysin näkökulmasta soveltuvaksi

The screenshot displays the Merlic software interface for configuring an image source. The main window is titled 'Image Sources' and contains several tabs: 'Image Sources', 'Communication', 'Recipes', and 'I/O'. The 'Image Sources' tab is active, showing a 'Configurations' table with columns for 'Type', 'Status', and 'Name'. The table lists three configurations: 'Basler' (active), 'HikVision' (inactive), and 'Wood' (inactive). The 'Basler' configuration is selected, and its details are shown in the 'Image' panel. The 'Image' panel displays a live video feed of a green, textured surface. Below the feed are buttons for 'Start live image' and 'Start snapshot'. An 'Info' panel below the feed provides details for the selected camera: Image source: Basler, Camera: 00305315591e_Basler_acA16..., Interface: GigEVision2, IP: 169.254.31.89/16, Status: Connected. To the right of the 'Image' panel is the 'EasyParams' section, which shows various camera parameters. The 'Automatic Exposure Control' section has three radio buttons: 'Off' (selected), 'Continuous', and 'Once'. Below it is the 'Exposure Time' slider, which is set to 1500. The 'Automatic Gain Control' section also has three radio buttons: 'Off' (selected), 'Continuous', and 'Once'. Below it is the 'Gain' slider, which is set to 1.00. The 'Trigger Method' section has a dropdown menu set to 'Software'. The 'Trigger Activation' section is empty. The 'Exposure Time' section has a text box and a note: 'Specify the required exposure time manually via the slider or the text field on the right. The slider shows only a recommended range. To see the entire value range and to set exact decimal values, use the parameter Exposure Time in the All Parameters tab.'

Type	Status	Name
Shared	active	Basler
Shared	inactive	HikVision
Shared	inactive	Wood

Image source	Basler
Camera	00305315591e_Basler_acA16...
Interface	GigEVision2
IP	169.254.31.89/16
Status	Connected

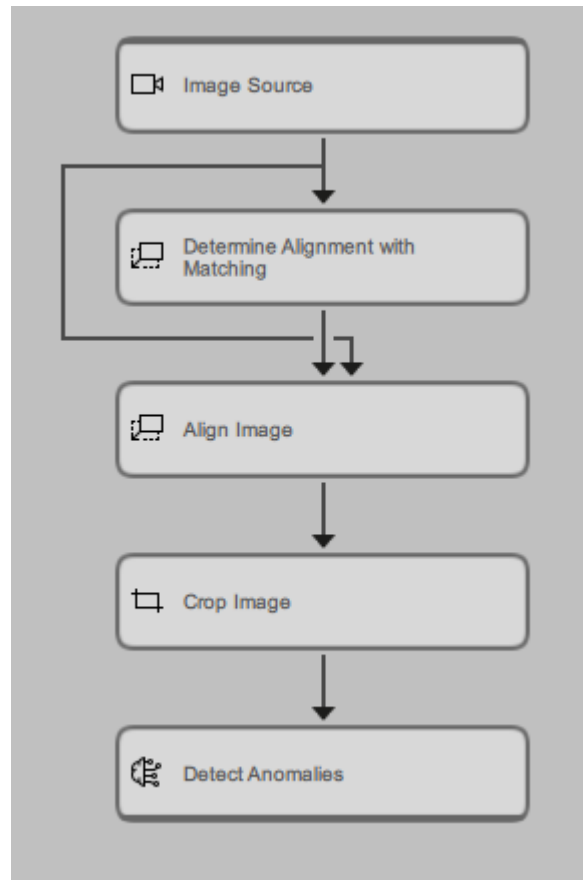
Analyysiohjelman rakentaminen

- Merlic-ohjelmistossa analyysin tekeminen tapahtuu pääsääntöisesti työkalupinoa (1.) rakentamalla ja näiden parametreja toisiinsa kytkemällä (graafinen ohjelmointi)
- Jokaisella työkalulla on input- ja output-parametrit (2. ja 3.)
- Työkalun asetuksia voidaan säätää sille varatusta ikkunasta (4.)
- Työkaluvalikosta voidaan etsiä sopivia työkaluja (5.), eli algoritmeja.

The screenshot displays the Merlic software interface, illustrating the process of building an analysis tool. The interface is divided into several key areas:

- 1. Tool Flow:** A vertical sequence of tool nodes: 'Image Source', 'Determine Alignment with Matching', 'Align Image', 'Crop Image', and 'Detect Anomalies'. Arrows indicate the flow between these tools.
- 2. Tool Configuration:** A detailed view of the 'Determine Alignment with Matching' tool. It shows input parameters: 'Image' (with a value of 0.5) and 'Orientation Tolerance' (with a value of 20.0). Below these are sections for 'Processing' and 'Training', each with a small image preview.
- 3. Output Data:** A section showing the output of the tool, including 'Alignment Data' (with a score of 1.0) and 'Tool State' (set to '[0; Ok]').
- 4. Image Alignment:** A large image showing a vertical strip of a landscape, with a green rectangular box highlighting a specific region of interest.
- 5. Tool Library:** A sidebar on the left containing a search bar and a list of tool categories: Acquisition, Calibration, Alignment, Preprocessing, Processing, Postprocessing, Evaluation, File Access, Communication (legacy), System, and Concept Tools.

Työkalupino



- Image Source -työkalulla otetaan kameralla kuva. Työkalu tuottaa ulostulon seuraavaan vaiheeseen, joka on kuva.
- Determine Alignment with Matching -työkalulla paikoitetaan kuvassa esiintyvä kappale esimerkiksi reunoista, rei'istä tai muusta selkeästä muodosta. Työkalu tuottaa paikoitusdatan ulostuloon
- Align Image -työkalulla yhdistetään kuva ja paikoitusdata, jolloin työkalu kääntää kuvassa esiintyvän kappaleen aina samaan orientaatioon. Tämä on tärkeää tehdä, koska kappale ei välttämättä tule kuva-alaan aina samassa orientaatioissa. Työkalu tuottaa ulostuloksi oikaistun kuvan.
- Crop Image -työkalulla rajataan otetusta kuvasta kiinnostusta alue, jolloin pikselimäärältään pienempää aluetta on tehokkaampi käsitellä. Työkalu tuottaa ulostuloksi leikatun kuvan.
- Detect Anomalies -työkalulla rakennetaan syväoppimismalli poikkeaman tunnistamista varten. Prosessi esitellään seuraavilla sivuilla tarkemmin.



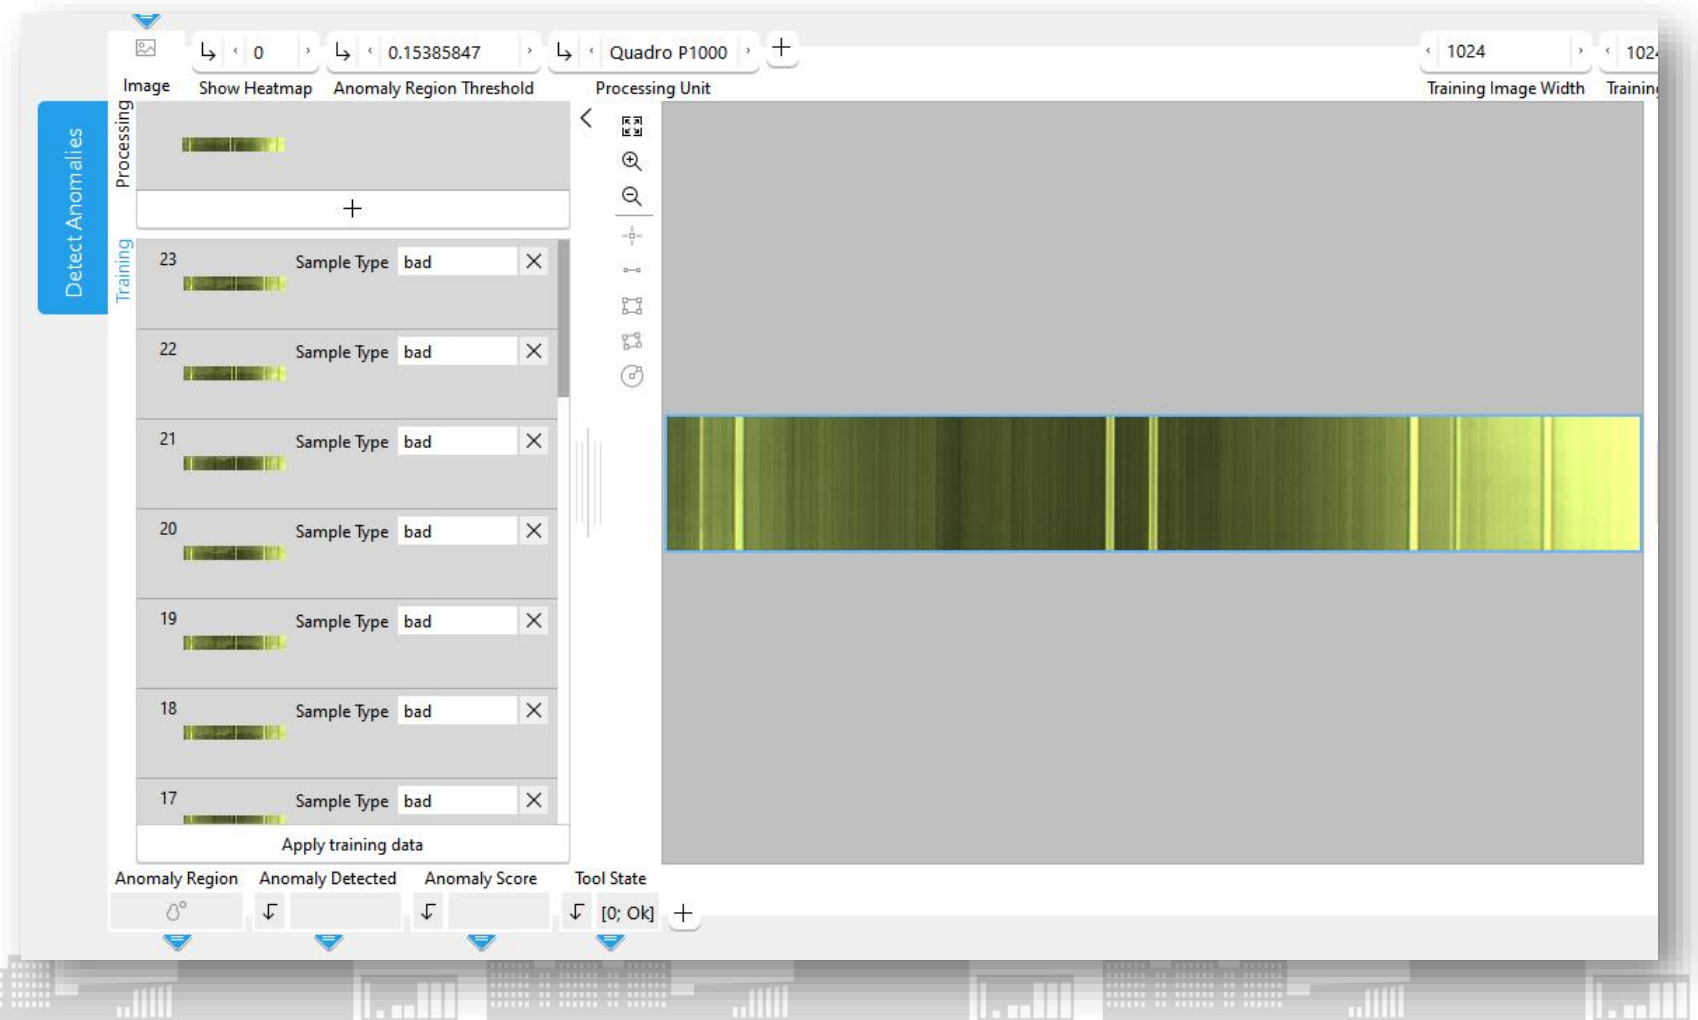
Deep Learning -mallin opetus

- Työkalun käyttöönotto aloitetaan mallin opettamisella
 - Merlic -ohjelmiston lähestymistapa vaatii ensisijaisesti opetuskuvia hyvistä kappaleista
 - Huonojen kappaleiden kuvilla voidaan tarvittaessa parantaa mallin laatua
 - Ohjelmisto vaatii vain 20-100 kuvaa luotettavan mallin opettamiseen
 - Luotettavuus tosin on aina tapauskohtaista ja välttämättä työkalu ei edes sovellu kaikenlaisten virheiden tai poikkeamien havaitsemiseen




Deep Learning -mallin opetus

- Ensin otetaan kuva ja sitten luokitellaan se joko hyväksi tai huonoksi
- Tätä prosessia toistetaan niin monta kertaa, että opetuskuvia saadaan riittävästi
- Merlic Deep Learning -lisäosan mukana tulee myös erillinen työkalu, jolla kuvien luokittelu ja opetusparametrien hallinta on laaja-alaisempaa



Deep Learning -mallin opetus

- Ennen opetuksen käynnistämistä säädetään siihen liittyvät parametrit
 - Usein opetus on iteratiivinen prosessi, jossa haetaan oikeat parametrit sovelluskohteeseen
 - Yleensä luotettavuutta edistävien parametrien arvojen kasvattaminen vaatii enemmän laskentatehoa ja -aikaa
 - Suoraviivaisissa tapauksissa kaikkien parametrien arvoihin ei tarvitse ottaa kantaa ja ne ovatkin oletuksena piilotettuna
 - Näitä parametreja saa näkyviin plus-merkin alta






- Muutamia tyypillisiä parametreja
 - Processing Unit -parametrilla valitaan laskentayksikkö. Lähtökohtaisesti kannattaa käyttää näytönohjainta nopeuden takia, jos se on tuettuna listassa.
 - Training Image Width ja Height -parametrit määrittävät opetuskuvien koon. Percentage of Pixels -parametri taas näistä kuvista käytettävien pikseleiden määrän. Suuremmat arvot parantavat mallin luotettavuutta, mutta vaativat enemmän laskenta-aikaa. Laskenta on optimaalista silloin, jos kuvakoko on jaollinen 32:lla.
 - Model Size -parametrilla valitaan esiopetettu malli. Lähtökohtaisesti kannattaa aloittaa medium-mallilla, mutta jos se ei toimi, niin voi kokeilla large-mallia. Sen käyttö vaatii enemmän suorituskykyä tuotantoajossa.
 - Image Complexity -parametri kuvaa mallin kykyä käsitellä monimutkaisia kuvia. Suurempia arvo vaatii enemmän opetusaikaa.
 - Maximum Number of Epochs -parametrilla määritellään se montako opetussykliä käydään koko datasetillä läpi. Välttämättä suurempi arvo ei takaa parempia tuloksia, mutta usein näin kuitenkin voi olla.




Deep Learning -mallin testaus

- Opetetun mallin luotettavuutta voidaan arvioida Training Error -arvon perusteella. Yleisesti se kuvaa sitä eroa, miten hyvin malli ennustaa opetusdataa vasten ja vertaa sitä tosiasialliseen tulokseen. Toisaalta liian pieni arvo voi kuvata ylisovitusta, joka taas johtaa huonoon tulokseen opetusdatasta poikkeavalla datalla.
- Opetettu malli antaa automaattisesti raja-arvon, joka määrittelee sisältääkö kuva poikkeaman vai ei. Tätä raja-arvoa voidaan tarvittaessa säätää manuaalisesti.
- Yksittäisen kuvan poikkeama-arvo (Anomaly Score) ja päätös poikkeaman olemassaolosta on näkyvillä työkalun ulostuloissa.




Deep Learning -mallin testaus




- Ensimmäinen virhetyyppi opetettiin 145 mm leveästä profiilista
- Testausta varten rakennettiin myös Merlic-ohjelmistolla on käyttöliittymä
- Käyttöliittymästä voi liipaista kuvan, nähdä hyväksytty/hylätty-tuloksen ja nähdä mallin raja-arvon, sekä kyseisen kuvan poikkeama-arvon
- Testauksessa otetaan muutamia kuvia satunnaisesti koko profiilin matkalta







Anomaly Threshold 0.1950
Anomaly Score 0.1857




Anomaly Threshold 0.1950
Anomaly Score 0.2162



Anomaly Threshold 0.1950
Anomaly Score 0.1779



Anomaly Threshold 0.1950
Anomaly Score 0.1722




Anomaly Threshold 0.1950
Anomaly Score 0.2139



Anomaly Threshold 0.1950
Anomaly Score 0.1853



Deep Learning -mallin testaus




- Toinen virhetyyppi opetettiin 40 mm leveästä profiilista
- Käyttöliittymästä voi liipaista kuvan, nähdä Testauksessa otetaan muutamia kuvia satunnaisesti koko profiilin matkalta





Anomaly Threshold 0.2841
Anomaly Score 0.2653



Anomaly Threshold 0.2841
Anomaly Score 0.2765



Anomaly Threshold 0.2841
Anomaly Score 0.2826



Anomaly Threshold 0.2841
Anomaly Score 0.2694




Anomaly Threshold 0.2841
Anomaly Score 0.2692



Anomaly Threshold 0.2841
Anomaly Score 0.2809



Deep Learning -mallin testaus



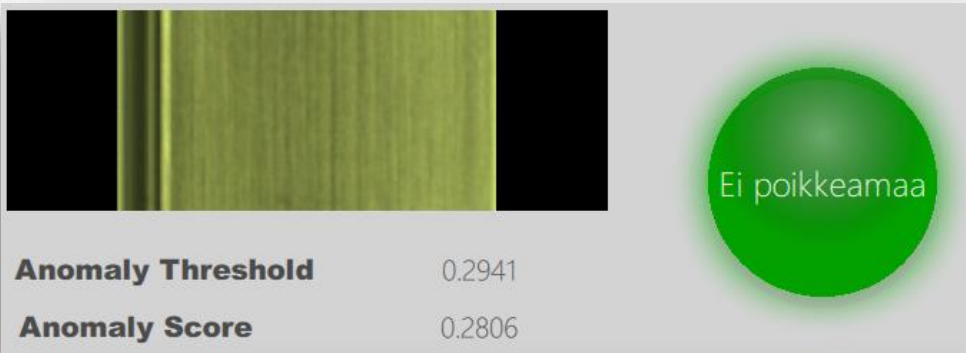
- Kolmas virhetyyppi opetettiin 35 mm leveästä pinnasta
- Profiilista oli virheetön testi pala ja koko matkalta virheellinen
- Testauksessa otetaan muutamia kuvia satunnaisesti molemmista profiileista





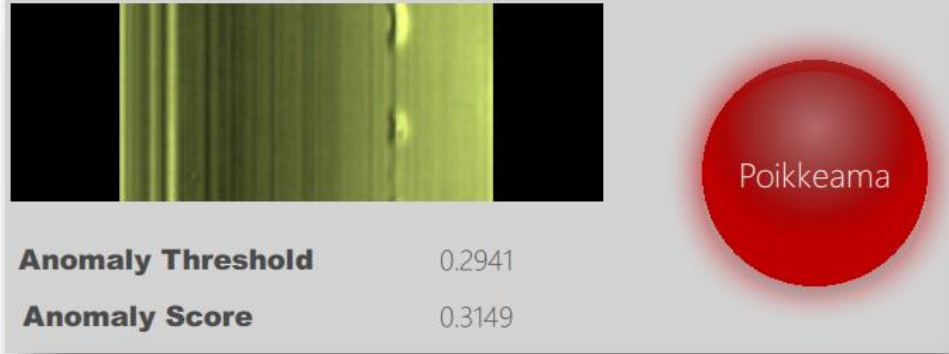
Anomaly Threshold 0.2941
Anomaly Score 0.3142

Poikkeama



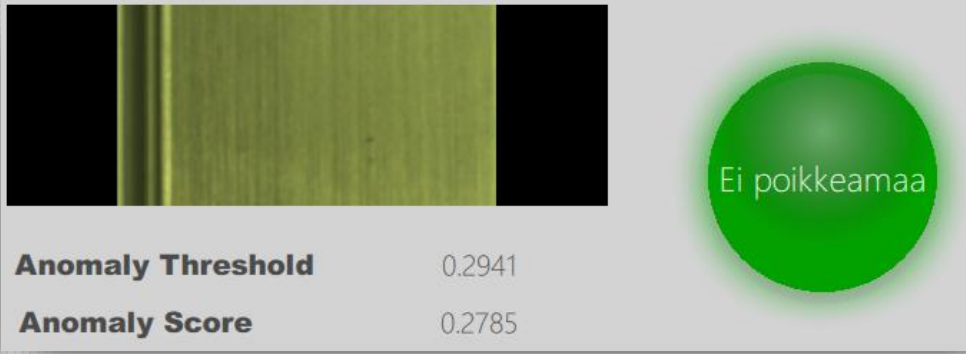
Anomaly Threshold 0.2941
Anomaly Score 0.2806

Ei poikkeamaa



Anomaly Threshold 0.2941
Anomaly Score 0.3149

Poikkeama



Anomaly Threshold 0.2941
Anomaly Score 0.2785

Ei poikkeamaa



Anomaly Threshold 0.2941
Anomaly Score 0.3147

Poikkeama



Anomaly Threshold 0.2941
Anomaly Score 0.2817

Ei poikkeamaa



Deep Learning -mallin testaus




- Neljäs virhetyyppi opetettiin 35 mm leveästä pinnasta. Pintaan tehtiin muutamia naarmuja ja piirrettiin tussia kaksi jälkeä
- Testauksessa otetaan muutamia kuvia profiilista (ehjä ja vioitettu) satunnaisesti
- Tässä tapauksessa testattiin myös kuvien filteröintiä siten, että profiilin normaalipinta saadaan käytännössä mustaksi, jolloin virheet nousevat paremmin esiin.
- Testikappaleisiin on saattanut tulla erilaisia hiusnaarmuja tai rasvajälkiä kuljetuksen yhteydessä, jotka näkyvät kuvassa, mutta ne eivät ole laatuongelmia.
- Todellisuudessa pursottimelta tulevassa profiilissa ei näitä ole






Ei poikkeamaa

Anomaly Threshold	0.2449
Anomaly Score	0.2345



Poikkeama

Anomaly Threshold	0.2449
Anomaly Score	0.2557




Ei poikkeamaa

Anomaly Threshold	0.2449
Anomaly Score	0.2362



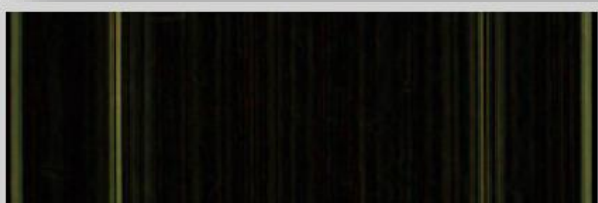
Poikkeama

Anomaly Threshold	0.2449
Anomaly Score	0.2746



Poikkeama

Anomaly Threshold	0.2449
Anomaly Score	0.3074



Ei poikkeamaa

Anomaly Threshold	0.2449
Anomaly Score	0.2387



Yhteenveto

- Deep Learning -menetelmä soveltui kohtuullisen hyvin testattujen laatuerojen havaitsemiseen ja luotettavuus oli pienelläkin kuvamäärällä hyvä
- Vaikka sovelluksessa olikin melko kirkas valaistus, ei valaistusolosuhteita saatu näillä vakioitua, vaan esim. aamulla otetut kuvat ja niillä opetettu malli ei välttämällä toiminut enää iltapäivän valaistusolosuhteissa.
- Tässä testausasetelmassa (laitteet, ohjelmistot, ympäristö) jokainen profiili piti opettaa erikseen ja jokaiselle profiilille piti tehdä oma analyysiohjelmansa. Merlic-ohjelmiston arkkitehtuuri on sellainen, että näitä analyysiohjelmiä (recipes) on mahdollista kutsua rajapinnan kautta.

